

Детектирование стресса по данным давления пульса крови с использованием персонализированных сверточных сетей

М. О. Доброхвалов[✉], А. Ю. Филатов

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия
[✉] night1337bot@gmail.com

Аннотация. Обнаружение стресса – это активная область исследований с важными последствиями для личного, профессионального и социального здоровья человека. Многие современные подходы используют признаки, вычисленные на основе нескольких сенсорных модальностей (таких, как электрокардиограмма, кожно-гальваническая реакция, температура кожи, дыхание, данные акселерометров и др.). В качестве методов решения задачи широко используют как традиционные алгоритмы машинного обучения (решающие деревья, дискриминантный анализ, метод опорных векторов и др.), так и нейронные сети (полносвязные, сверточные, рекуррентные). Использование классических методов, а также полносвязных нейронных сетей требует больших объемов данных для извлечения особенностей. В различных исследованиях рассматриваются субъекто-независимые и субъекто-зависимые (изначально персональные или адаптированные) модели. Целью статьи служат применение персонализации для сверточных нейронных сетей для детектирования стресса на основе данных variability сердечного ритма, а также реализация метода сверточной нейронной сети. Исследуются модификации с использованием различных слоев уменьшения размерности данных, например одномерный сверточный слой, максимизирующий и усредняющий пулинги. Также исследуется влияние использования численной производной variability сердечного ритма как дополнительной информации во входных данных. В данной статье продемонстрирована важность персонализации моделей, если данная возможность имеется, так как это позволяет увеличивать точность моделей для конкретных субъектов. Предлагаемый метод на основании 60 интервалов между ударами сердца бинарно определяет, находится ли человек в состоянии стресса. До персонализации зафиксирована точность детектирования состояния 0.853, значение F_1 -меры – 0.901, после персонализации – 0.942 ± 0.095 .

Ключевые слова: обнаружение стресса, сверточная нейронная сеть, машинное обучение, variability сердечного ритма, субъекто-зависимые модели

Для цитирования: Доброхвалов М. О., Филатов А. Ю. Детектирование стресса по данным давления пульса крови с использованием персонализированных сверточных сетей // Изв. СПбГЭТУ «ЛЭТИ». 2024. Т. 17, № 1. С. 55–67. doi: 10.32603/2071-8985-2024-17-1-55-67.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Благодарность. Статья подготовлена в рамках проекта «Методы гибридного интеллекта для построения гетерогенных многоагентных систем с самообучением и самоорганизацией» программы развития СПбГЭТУ «ЛЭТИ».

Original article

Stress Detection from Blood Volume Pulse Data Using Customized Convolutional Networks

М. О. Dobrokhvalov[✉], A. Yu. Filatov

Saint Petersburg Electrotechnical University, Saint Petersburg, Russia
[✉] night1337bot@gmail.com

Abstract. Stress detection is a popular research direction due to its important implications for personal, occupational, and social health. A number of current approaches use features computed from multiple sensory

modalities (such as electrocardiogram, galvanic skin response, skin temperature, respiration, accelerometer data, and others). Both classic machine learning algorithms (decision trees, discriminant analysis, support vector machines, etc.) and neural networks (fully connected, convolutional, recurrent) are widely used as methods for solving this problem. The use of classic methods, as well as fully connected neural networks, requires large amounts of data to extract features. Various studies examine subject-independent and subject-dependent (initially personal or adapted) models. This work is aimed at developing and implementing a method based on the principle of customization of convolutional neural networks for stress detection based on heart rate variability data. The proposed method is a convolutional neural network. The work explores modifications using various dimensionality reduction layers, such as a one-dimensional convolutional layer, maximizing and averaging pooling. The impact of using the numerical derivative of heart rate variability as additional information in the input data is also explored. This work demonstrates the importance of customized models, if this opportunity is available, due to their increased accuracy and reliability. The proposed method, based on 60 intervals between heartbeats, binary determines whether a person experiences stress. Prior to customization, detection accuracy is 0.853, f1-measure value is 0.901. The accuracy of stress detection after customization reaches 0.942 ± 0.095 .

Keywords: stress detection, convolutional neural network, machine learning, heart rate variability, subject-dependent models

For citation: Dobrokhvalov M. O., Filatov A. Yu. Stress Detection from Blood Volume Pulse Data Using Customized Convolutional Networks // LETI Transactions on Electrical Engineering & Computer Science. 2024. Vol. 17, no. 1. P. 55–67. doi: 10.32603/2071-8985-2024-17-1-55-67.

Conflict of interest. The authors declare no conflicts of interest.

Acknowledgements. The article was prepared within the framework of the project «methods of hybrid intelligence for building heterogeneous multi-agent systems with self-learning and self-organization» of the Saint Petersburg Electrotechnical University development program.

Введение. Стресс служит реакцией тела на воспринимаемые физические или психологические угрозы [1] и определяется как переход от спокойного состояния к возбужденному, вызывающему определенный набор физиологических реакций [2]. Более того, детектирование стресса играет важную роль в решении таких проблем со здоровьем, как депрессия, тревожность, инфаркты и инсульты [3]. Стресс также влияет на способность человека принимать решения, устойчивость внимания, способность к обучению и решению проблем [4], поэтому так важно определить его своевременно.

Для решения данной задачи в различных исследованиях используются разные классические методы машинного обучения, а также нейронные сети. В качестве входных данных для определения стресса используются данные различных датчиков – электрокардиограмма (ЭКГ, ECG), кожно-гальваническая реакция (КГР, GSR) или электрическая активность кожи (ЭАК, EDA), фотоплетизмограмма (PPG), давление пульса крови (BVP), электромиограмма (ЭМГ, EMG), дыхание, телесные акселерометры и др. В [5] авторы успешно применили в нейронной сети персонализацию данных электрической активности кожи. Таким образом, цель статьи заключается в разра-

ботке метода детектирования стресса на основе данных variability сердечного ритма с учетом процесса персонализации сверточных нейронных сетей, а также реализация данного метода. Предлагаемый подход конкурентоспособен по сравнению с другими современными методами.

Обзор предметной области. К настоящему времени проводились различные исследования в области детектирования стресса на основе физиологических датчиков [6]–[9]. Здесь будут описаны основные неинвазивно получаемые данные, которые используются для определения функционального состояния человека. Также будут перечислены наиболее распространенные методы решения задачи и подходы к процессу обучения модели (общие и персонализированные модели).

Для определения стресса обычно используются данные, полученные с помощью неинвазивных датчиков, например связанные с работой сердца, а именно: электрокардиограмма [3], [10]–[13], фотоплетизмограмма [14]–[15], частота сердечных сокращений [7], [16]–[19], variability сердечного ритма (BCP) [13], [20]–[23]. Также часто используется электрическая активность кожи (ЭАК) или кожно-гальваническая реакция (КГР) [5], [7], [22]–[24]. При определении

стресса у человека используются также частота дыхания [7], [25], электроэнцефалограмма [12], электромиограмма [12], температура кожи [18], [25]–[26], акселерометрия [26]–[28] и др.

При определении стресса в современных исследованиях применяются методы машинного обучения. Обзорных актуальных публикаций в данной области представлен в табл. 1. Castaldo и другие авторы [6] демонстрируют дерево принятия решений, построенное с помощью алгоритма C4.5 [28], которое в рамках их исследований показывает результат лучше, чем методы AdaBoosting, многослойный перцептрон, метод опорных векторов и классический байесовский классификатор. В исследованиях Indikawati и Winiarti [29] наилучший результат продемонстрировал случайный лес. Iqbal и др. [17] описывают использование классификатора, основанного на логисти-

ческой регрессии. В Liapis и др. [24] наибольшую точность продемонстрировал классификатор sTree. Wu и др. [27] использовали 4 метода: наивный байесовский классификатор, дерево принятия решений, построенное с помощью алгоритма C4.5, случайный лес и бэггинг с использованием C4.5. В результате сравнения установили, что наиболее высокую точность дает метод бэггинг. В [30] Talukdar и др. наибольшую точность (83.11 %) продемонстрировал случайный лес. Nantono и др. [31] сравнивали многослойный перцептрон, метод k ближайших соседей (kNN), линейный дискриминантный анализ и наивный байесовский классификатор. Наилучший результат показал kNN. Rodríguez-Arce и др. в [25] демонстрируют, что классические методы машинного обучения могут достигать точности более 95 % при использовании данных от множества

Табл. 1. Обзор актуальных работ
Tab. 1. Literature review

Источник	Год	Набор данных	Количество субъектов	Данные	Модели	Точность
[2]	2018	WESAD	15	ECG, EDA, BVP, Temp, Resp, EMG, ACC	kNN, DT, RF, LDA , AB	0.928
[2]	2018	WESAD	15	ECG	kNN, DT, RF, LDA , AB	0.854
[3]	2020	WESAD	15	ECG, EDA, BVP, Temp, Resp, EMG, ACC	kNN, SVM, AB, FCN	0.952
[4]	2020	WESAD	15	EDA	kNN , SVM, RF	0.916
[5]	2021	WESAD	15	EDA	CNN	0.929
[6]	2016	Other	42	ECG	C4.5 tree	0.790
[7]	2018	Other	58	HR, EDA, Resp	FCN	0.897
[8]	2019	Affective ROAD, Other	9, 17	ECG	FCN	0.902
[14]	2021	UBFC-Phys	56	BVP	SVM , LR, kNN	0.855
[15]	2022	UBFC-Phys	56	BVP	CNN-MLP	0.820
[16]	2020	Other	20, 3	HR, EDA	CNN	0.825, 0.938
[17]	2021	WESAD	15	ECG, EDA, BVP, Temp, Resp, EMG, ACC	LR	0.857
[18]	2019	WESAD	15	Temp, BVP, HR	LDA , QDA, RF	0.874 ± ± 0.104
[24]	2021	WESAD	15	EDA	sTree	0.958
[27]	2015	Other	8	HRV, ACC	Bagging	0.857
[29]	2020	WESAD	15	EDA, BVP, Acc, Temp	RF , DT, LR	0.967 ± ± 0.032
[30]	2022	UBFC-Phys	56	Visual → BVP	RF	0.831
[31]	2020	Other	41	BVP	kNN , LDA, FCN	0.820
[33]	2022	WESAD	15	BVP	FCN	0.990
[34]	2021	Other	27	ECG	kNN, SVM , FCN, RF, GB	0.830
[35]	2019	Other	20	ECG	CNN	0.827
[36]	2022	WESAD	15	ECG, EDA, BVP, Temp, Resp, EMG, ACC	CNN using GAF	0.948
[37]	2023	UBFC-Phys	56	BVP, EDA	CNN+LSTM+FCN	0.818

модальностей. Сравнить результаты с аналогами не представляется возможным, так как используемые данные не относятся к публичным. Aqajari и др. в [4] показали наибольшую точность kNN по сравнению с RF, SVM, наивным байесовским классификатором. Siirtola в [18] указывает, что наилучший результат продемонстрировал линейный дискриминантный анализ. Также Siirtola и Rönning в [32] сравнивают модели классификации и регрессии. Используемая модель классификации – случайный лес, а регрессионная модель – бэггинг на основе дерева. В публикации сделан вывод, что модели регрессии превосходят модели классификации при разделении на 2 класса (стресс и его отсутствие).

Нейронные сети также служат одним из подходов к решению задачи. Al Abdi и др. [7] сравнивают следующие методы: логистическую регрессию, многослойный перцептрон, наивный байесовский классификатор, случайный лес и K*. Среди перечисленных методов наилучший результат показал многослойный перцептрон. Также данный метод показал наибольшую точность в [3], [33]. Sabour и др. [14] описывают использование классических методов машинного обучения на предлагаемых ими данных. Исследуемые методы: метод опорных векторов, метод k ближайших соседей и логистическая регрессия. Наилучший результат (85.48 %) показал метод опорных векторов с ядром радиальной базисной функции и вычисленными метриками фотоплетизмограммы в качестве входных данных. Hasanpoor и др. [15] достигли точности 82 % с помощью модели, объединяющей многослойный перцептрон и полносвязную нейронную сеть. Oskooei и др. [20] демонстрируют, что использование временных и частотных характеристик ВСР не удовлетворительны при использовании классического классификатора kNN. Поэтому в качестве автокодировщиков использовали сверточные сети и сети долгой краткосрочной памяти с последующей кластеризацией. Результаты сверточной сети имели разделимые классы, в отличие от моделей, обученных исходных данных и данных, закодированных LSTM-кодировщиком. Woodward и др. [16] демонстрируют сверточную нейронную сеть, обученную на собственных данных, которая демонстрирует точность детектирования около 93.9 %. Исследование проводилось всего на

3 субъектах, поэтому его результаты не могут считаться репрезентативными. Cho и др. [8] изначально обучают сверточную сеть на большом датасете, содержащем реакцию людей на вождение в различных условиях, после чего сеть дообучается на данных, связанных с решением математических задач. Дообученная сеть показывает результаты лучше, чем та, которая тренировалась только на данных с математическими задачами. He и др. в [35] демонстрируют, что сверточная сеть показывает результаты лучше, чем линейный дискриминантный анализ и метод опорных векторов. Также в последующей своей публикации [9] He и Jiang исследуют возможность уточнения порога отнесения вероятности к классам. Ghosh [36] описывает применение нейронных сетей, в качестве входных данных используется угловое поле Грамма (Gramian Angular Field). Sah и Ghasemzadeh в [5] описывают обучение нейронной сети с последующей персонализацией.

Таким образом, в области определения стресса используются как классические методы машинного обучения, так и нейронные сети. В последние годы появляется больше исследований с применением нейронных сетей. Классические нейронные сети требуют в качестве входных данных некоторой предобработки и вычисления особенностей, сверточные нейронные сети позволяют избежать этого.

К областям, в которых наблюдается некоторое разделение мнений, относится выбор подхода к персонализации или общности моделей относительно субъектов. Можно отметить использование субъекто-зависимых и -независимых подходов в обучении. Субъекто-независимые модели предполагают построение единой модели для всех субъектов независимо от любых параметров субъекта. Субъекто-зависимые модели предполагают уникальную модель для каждого человека (или для группы людей с некоторыми схожими особенностями).

Большое количество работ в исследуемой области были направлены на создание именно общих моделей без учета персональных особенностей субъектов. Например, Liaris и др. в [24] демонстрируют, что общие модели обеспечивают достаточно высокую точность, сравнивая несколько различных классификаторов.

Как уже было сказано, субъектно-зависимые модели предполагают уникальную модель для каж-

дого субъекта (или некоторой подгруппы). Также данную область можно разделить на 2 подгруппы: персональные и адаптированные модели. Персональные модели – это модели, которые изначально обучались только на данных субъекта. Адаптированные модели предполагают изначальное обучение на некотором общем наборе данных с последующим уточнением для конкретного субъекта.

Так Ху и др. [38] указывают, что у людей могут быть схожие паттерны в данных с различных сенсоров. На основе этой информации описывается разделение участников на группы со схожими паттернами с последующим использованием уникального детектора стресса для каждой группы. Ninh и др. [39], используя сигнал EDA с низким разрешением, показывают, что субъектно-зависимая модель статистически более точна, чем субъектно-независимая, с точки зрения разделения паттернов стресса и его отсутствия.

Сежа и Врена [40] описывают построение персонализированной модели на основе общей. Таким образом исходная модель изначально обучается на большем наборе данных для более широкой возможности обобщения, после чего модель дообучается и уточняется на данных, специфичных для конкретного пользователя. Ли и др. в [41] также описывают уточнение персонализированной модели. Для обнаружения стресса в работе в качестве входных данных используется речь человека. Sah и Ghasemzadeh [5] используют данные EDA и демонстрируют, что для большинства исследуемых субъектов точность повышалась после процесса обучения на данных конкретного субъекта.

Материалы и методы. Здесь описываются данные, используемые в данном исследовании, а также демонстрируется предлагаемая архитектура нейронной сети. Описываются используемые в дальнейшем метрики, с помощью которых сравниваются предлагаемые модификации.

Во многих исследованиях, проводимых в области детектирования стресса, используются данные, собранные учеными самостоятельно. В рамках этого исследования используется датасет [14] – публичный датасет, содержащий давление пульса крови, электрическую активность кожи, а также видео процесса проведения теста. В датасете представлены данные 56 субъектов, однако в рамках этого исследования используются данные только 15 субъектов. Остальные субъекты были исключены в соответствии с причина-

ми, описанными в публикации авторов набора данных. RR-интервалы вычислялись из давления пульса крови с помощью библиотеки BioSPPy*. Оба теста (выступление перед аудиторией и выполнение арифметических операций на время) были обозначены как состояния стресса.

Дальше – RR-интервал, т. е. интервал между соседними ударами сердца. Интервал – набор RR-интервалов, используемый в качестве входных данных.

Здесь будет описана архитектура нейронной сети, показывающей наибольшую точность на данных датасета UBFC-Phys. Сверточная нейронная сеть [16] продемонстрировала достаточно высокую точность, поэтому была выбрана архитектура линейной сверточной сети.

Архитектура сети представляет собой последовательное использование блока ConvX (рис. 1) и слоя уменьшения размерности (рис. 2). Блок ConvX состоит из одномерного сверточного слоя с размером ядра 3 (Conv1D), слоя пакетной нормализации (BatchNorm) и слоя активации ReLU. На рис. 2 представлена архитектура сети для интервала длиной 60. Данная длина была выбрана, поскольку во многих публикациях [2], [5], [17], [19], [34] используется окно в 60 с. Количество секунд и ударов – разные единицы измерения, однако их можно сопоставлять, так как нормальное количество ударов сердца в минуту в состоянии покоя у человека варьируется от 60 до 100 [42]. В скобках указано количество слоев входного сигнала. *in* в первом блоке ConvX обозначает, что во входных данных может присутствовать или отсутствовать слой, содержащий разницу между соседними RR-интервалами (численную производную). В качестве блока уменьшения размерности рассматривались одномерная свертка ($\text{kernel} = 2$, $\text{stride} = 2$), максимизирующий пулинг ($\text{kernel} = 2$) и усредняющий пулинг ($\text{kernel} = 2$). Архитектура частично зависит от максимальной длины интервала. Целью было сформировать архитектуру, в которой после каждого блока ConvX можно было бы добавить уровень уменьшения размерности (кроме первого и последнего). Таким образом, данная архитектура позволила получить необходимую размерность данных за счет сверточных слоев и слоев умень-

* URL: <https://biosppy.readthedocs.io/en/latest/>.

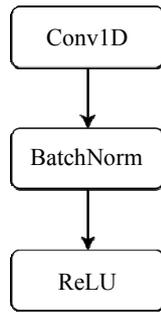


Рис. 1. Блок ConvX
Fig. 1. The ConvX block

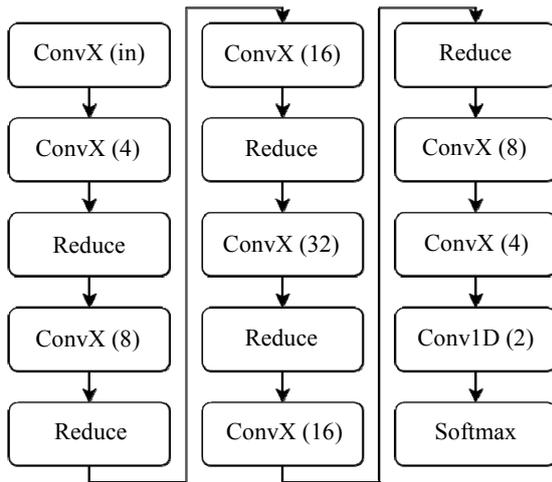


Рис. 2. Архитектура сети
Fig. 2. Network architecture

шения размерности (без использования полносвязных слоев). Результаты исследований выбора модификаций представлены далее.

Эксперименты проводились с использованием процессора Intel® Core™ i5-8300H CPU @ 2.30 Гц, 16 Гбайт RAM памяти частотой 2667 МГц и графического процессора NVIDIA GeForce GTX 1050 Mobile 4096 MiB VRAM. Использовалась 64-битная операционная система Ubuntu 22.04.1 LTS. Используемые в данной статье метрики представлены в табл. 2: TP (True Positive) – количество верно отнесенных объектов к рассматриваемому классу; TN (True Negative) – количество объектов, верно не отнесенных к рассматриваемому классу; FP (False Positive) – количество объектов, неверно отнесенных к рассматриваемому классу; FN (False Negative) – количество объектов, неверно не отнесенных к рассматриваемому классу. Также в статье используется метрика ROC AUC [24]. Данные метрики широко используются в области валидации нейронных сетей. Данные в датасете UBFC-Phys несбалансированы (imbalanced), поэтому F_1 -score является важной метрикой [19].

Табл. 2. Метрики
Tab. 2. Metrics

Метрика	Формула
Точность	$\frac{TP + TN}{TP + TN + FP + FN}$
Четкость (precision)	$\frac{TP}{TP + FP}$
Полнота (чувствительность, recall, true positive rate, TPR)	$\frac{TP}{TP + FN}$
F_1 -мера	$\frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$
Специфичность (true negative rate, TNR)	$\frac{TN}{TN + FP}$
Сбалансированная точность	$\frac{TPR + TNR}{2}$

Результаты. Здесь будет представлено сравнение двух типов модификаций – использование различных слоев для уменьшения размерности и использование численной производной. Также будет представлено влияние персонализации (адаптирования) модели для конкретного субъекта.

Все модификации сверточной нейронной сети, предложенные в процессе исследований, были реализованы в рамках данного исследования с использованием фреймворка PyTorch*. Во всех экспериментах применялась функция потерь CrossEntropy, использовался оптимизатор ASGD (с параметрами по умолчанию), количество эпох – 50, размер пакета – 8.

Здесь же представлено сравнение значений метрик различных предложенных модификаций (табл. 3) при тестировании с использованием всех данных (без пропуска субъектов). Заголовки столбцов формируют модификацию исследуемой сети. Во второй строке представлен способ уменьшения размерности в данной модификации, а в 3-й строке – использование численной производной во входных данных.

Как упоминалось ранее, в качестве способов уменьшения размерности рассматривались одномерная свертка, максимизирующий и усредняющий пулинги. При сравнении различных способов уменьшения размерности без использования численной производной во входных данных можно увидеть, что наибольшую точность показала модификация с усредняющим пулингом. Однако при использовании численной производной наибольшую точность показала модификация с максимизирующим пулингом. Использование

* URL: <https://pytorch.org/>.

Табл. 3. Значение метрик различных модификаций
Tab. 3. Metrics values of various modifications

Метрики	Модификация сети					
	Усредняющий пулинг		Максимизирующий пулинг		Одномерная свертка	
	Нет	Да	Нет	Да	Нет	Да
Точность	0.853	0.823	0.835	0.829	0.810	0.786
Смещенная точность	0.812	0.752	0.761	0.787	0.736	0.720
Четкость	0.857	0.808	0.811	0.843	0.798	0.794
Полнота	0.936	0.963	0.982	0.913	0.959	0.917
F ₁ -мера	0.895	0.879	0.888	0.877	0.871	0.851
roc auc	0.812	0.752	0.761	0.787	0.736	0.720

Табл. 4. Достоверность персонализированной модели каждого субъекта
Tab. 4. Reliability of the personalized model of each subject

Субъект	Модификация сети					
	Усредняющий пулинг		Максимизирующий пулинг		Одномерная свертка	
	Нет	Да	Нет	Да	Нет	Да
2	1	0.857	1	0.952	1	0.810
7	1	1	0.944	0.944	0.944	1
15	1	1	0.956	1	0.956	0.826
16	0.857	0.857	0.857	0.762	0.762	0.714
18	1	1	1	1	1	0.960
20	1	1	1	1	1	0.808
23	1	1	1	1	1	0.954
24	0.762	0.714	0.762	0.714	0.810	0.810
29	0.722	0.833	0.778	0.667	0.944	0.722
34	0.895	1	0.842	1	0.842	1
36	1	1	1	1	1	0.964
43	1	1	1	1	1	1
44	0.895	0.684	0.737	0.737	0.684	0.632
46	1	1	1	1	1	1
51	1	1	1	1	0.684	0.737
Среднее значение	0.942	0.93	0.925	0.918	0.908	0.862
Стандартное отклонение	0.095	0.112	0.101	0.127	0.119	0.127

численной производной показало негативные результаты. Модели без численной производной для всех методов уменьшения размерности демонстрировали большую точность.

Наибольшее значение всех метрик (точность – 0.853, смещенная точность – 0.812, четкость – 0.857, F₁-мера – 0.895), кроме полноты, имеет модификация с усредняющим пулингом без численной производной. Наибольшее значение полноты имеет модификация с максимизирующим пулингом без численной производной – 0.982. Для всех модификаций максимальная точность достигалась после 30-й эпохи, но 95 % максимальной точности было достигнуто в первые 10 эпох, потому что точность некоторых субъектов достигала почти 100 %, а в процессе дальнейшего обучения точность для остальных испытуемых увеличивалась.

а в процессе дальнейшего обучения точность для остальных испытуемых увеличивалась.

Как было указано ранее, у разных подходов к персонализации моделей могут быть свои преимущества и недостатки. Для субъектных моделей необходимо большое количество данных, общие – не учитывают уникальности субъектов. Персонализация может решить подобные проблемы. Другим решением может стать поиск людей со схожими паттернами интервалов или, в более простом варианте, со схожими биологическими признаками – пол, возраст, этническая принадлежность и т. д.

Для персонализации рассматривался подход leave-one-subject-out (LOSO) [43]. Один субъект

Табл. 5. Значение метрик лучшей модели до и после персонализации
Tab. 5. Metrics values of best model before and after personalization

Субъект	Точность			Смещенная точность	Четкость	Полнота	F_1 -мера	roc auc
	До	После	Разность					
2	0.905	1	0.095	1	1	1	1	1
7	0.722	1	0.278	1	1	1	1	1
15	0.609	1	0.391	1	1	1	1	1
16	0.619	0.857	0.238	0.857	0.923	0.857	0.889	0.857
18	0.840	1	0.16	1	1	1	1	1
20	0.808	1	0.192	1	1	1	1	1
23	0.500	1	0.5	1	1	1	1	1
24	0.667	0.762	0.095	0.75	0.846	0.786	0.815	0.75
29	0.444	0.722	0.278	0.625	0.733	0.917	0.815	0.625
34	0.737	0.895	0.158	0.923	1	0.846	0.917	0.923
36	0.893	1	0.107	1	1	1	1	1
43	0.960	1	0.04	1	1	1	1	1
44	0.579	0.895	0.316	0.878	0.923	0.923	0.923	0.878
46	0.954	1	0.045	1	1	1	1	1
51	0.632	1	0.368	1	1	1	1	1

изначально не попадает в тренировочную выборку. Модель обучается на данных других субъектов. После этого вычисляется точность для тестовой выборки пропущенного субъекта, необходимая для последующего сравнения. Сеть дообучается на тренировочных данных этого субъекта. Затем повторно вычислялась точность. Как было указано ранее, процесс персонализации был выполнен для всех модификаций. Точность после персонализации для модификаций представлена в табл. 4. В строках представлены субъекты, столбцы формируют исследуемую модификацию аналогично заголовкам табл. 3. На основании табл. 4 можно сделать вывод, что персональные модели всех модификаций дают в среднем примерно одинаковый результат. Наибольшую усредненную по пользователям точность показывает модификация без численной производной и с усредняющим пулингом. Разница точности до и после персонализации модели представлена в табл. 5. Также в таблице указаны значения других метрик. Можно увидеть, что персонализация позволила увеличить точность для каждого субъекта. Изначальная сравнительно низкая точность связана с тем, что у каждого субъекта могут отличаться значения RR-интервалов в различных состояниях.

В табл. 6 представлено сравнение точности предложенной модели с аналогами. На основании таблицы видно, что предложенная сеть демонстрирует более высокую точность, чем рассмотренные аналоги. Однако точность предложенной модификации на датасете UBFC-Phys ниже, чем точность

Табл. 6. Значение метрик лучшей модели до и после персонализации
Tab. 6. Metrics values of the best model before and after personalization

Статья	Метод	Данные	Точность
[14]	SVM (linear kernel)	BVP	0.75
[14]	SVM (RBF kernel)	PPG	0.855
[14]	SVM (RBF kernel)	EDA	0.824
[14]	SVM (linear kernel)	BVP + EDA	0.795
[15]	CNN-MLP	PPG	0.82
[30]	RF	Visual → PPG	0.831
[37]	CNN + LSTM + FCN	BVP, EDA	0.818
Предлагаемое решение (общая модель)	CNN	PPG	0.853
Предлагаемое решение (модели с персонализацией)	CNN	PPG	0.942 ± ± 0.095

метода, предложенного в [33], на датасете WESAD. Так как источники данных различаются, возможность сравнить результаты отсутствует.

Выводы и заключение. В данной исследовательской работе предлагается сверточная нейронная сеть для классификации психического стресса человека. В качестве входных данных рассматривались наборы последовательных RR-интервалов, вычисленные на основе данных фотоплетизмографии датасета UBFC-Phys. Также рассматривались различные модификации сверточных

нейронных сетей для решения задачи детектирования стресса. В качестве модификаций рассматривались: 1) используемый для уменьшения размерности слой (рассматривались сверточный слой, усредняющий пулинг и максимизирующий пулинг); 2) численная производная, вычисленная относительно RR-интервалов. В статье предлагается изначальное обучение сети на общих данных с последующей персонализацией модели для каждого отдельного субъекта. Лучшей моделью, показавшей наивысшую среднюю точность после персонализации, стала сеть, использующая усредняющий пу-

линг, без добавления численной производной к входным данным. Точность модели на общих данных составляет 0.853. Точность, полученная после персонализации, равна 0.942 ± 0.095 .

В качестве дальнейших планов рассматривается возможность переносимости обучения между датасетами UBFC-Phys и WESAD. Также предполагается определение точности на основе датасета SWELL. В качестве другой области исследования рассматривается использование других входных данных, например электрической активности кожи, в совокупности с уже используемыми.

Список литературы

1. Selye H. The stress of life. New York: McGraw-Hill, 1976. 516 с.
2. Kasl S. V. Stress and health // Ann. Rev. of Public Health. 1984. Т. 5, № 1. P. 319–341.
3. Bobade P., Vani M. Stress detection with machine learning and deep learning using multimodal physiological data // 2020 Second Intern. Conf. on Inventive Research in Comp. Appl. (ICIRCA). Coimbatore, India: IEEE, 2020. P. 51–57. doi: 10.1109/icirca48905.2020.9183244.
4. GSR analysis for stress: Development and validation of an open source tool for noisy naturalistic GSR data / S. A. Aqajari, E. K. Naeini, M. A. Mehrabadi, S. Labbaf, A. M. Rahmani, N. Dutt. 2020. URL: <https://arxiv.org/ftp/arxiv/papers/2005/2005.01834.pdf> (дата обращения 21.08.2023).
5. Sah R. K., Ghasemzadeh H. Stress classification and personalization: Getting the most out of the least. 2021. URL: <https://arxiv.org/pdf/2107.05666.pdf> (дата обращения 21.08.2023).
6. Detection of mental stress due to oral academic examination via ultra-short-term HRV analysis / R. Castaldo, W. Xu, P. Melillo, L. Pecchia, L. Santamaria, C. James // 2016 38th Ann. Intern. Conf. of the IEEE Engin. in Med. and Biol. society (EMBC). IEEE, 2016. P. 3805–3808. doi: 10.1109/embc.2016.7591557.
7. Objective detection of chronic stress using physiological parameters / R. M. Al Abdi, A. E. Alhitary, E. W. Abdul Hay, A. K. Al-Bashir // Med. & Boil. Engin. & Comp. 2018. Т. 56. P. 2273–2286. doi: 10.1007/s11517-018-1854-8.
8. Ambulatory and laboratory stress detection based on raw electrocardiogram signals using a convolutional neural network / H. M. Cho, H. Park, S. Y. Dong, I. Youn // Sensors. 2019. Т. 19. № 20. P. 4408. doi: 10.3390/s19204408.
9. He J., Jiang N. Optimizing probability threshold of convolution neural network to improve HRV-based acute stress detection performance // 2019 41st Ann. Intern. Conf. of the IEEE Engin. in Med. and Biol. Society (EMBC). Berlin, Germany: IEEE, 2019. P. 5318–5321. doi: 10.1109/embc.2019.8856853.
10. Introducing WESAD, a multimodal dataset for wearable stress and affect detection / P. Schmidt, A. Reiss, R. Duerichen, C. Marberger, K. Van Laerhoven // Proc. of the 20th ACM Intern. Conf. on Multimodal Interaction. 2018. P. 400–408. doi: 10.1145/3242969.3242985.
11. Giannakakis G., Marias K., Tsiknakis M. A stress recognition system using HRV parameters and machine learning techniques // 2019 8th Intern. Conf. on Affective Comp. and Intelligent Interaction Workshops and Demos (ACIIW). Cambridge, UK: IEEE, 2019. P. 269–272. doi: 10.1109/aciw.2019.8925142.
12. Dalal S., Khalaf O. I. Prediction of occupation stress by implementing convolutional neural network techniques // J. of Cases on Information Technol. (JCIT). 2021. Т. 23, № 3. P. 27–42. doi: 10.4018/jcit.20210701.oa3.
13. ECG-based biometric under different psychological stress states / R. Zhou, C. Wang, P. Zhang, X. Chen, L. Du, P. Wang, Z. Zhao, M. Du, Z. Fang // Comp. Methods and Programs in Biomed. 2021. Т. 202. P. 106005. doi: 10.1016/j.cmpb.2021.106005.
14. UBFC-phys: A multimodal database for psychophysiological studies of social stress / R. M. Sabour, Y. Benezeth, P. De Oliveira, J. Chappe, F. Yang // IEEE Transactions on Affective Comp. 2021. Vol. 14, № 1. P. 622–636. doi: 10.1109/taffc.2021.3056960. URL: <https://ieeexplore.ieee.org/document/9346017> (дата обращения 21.08.2023).
15. Stress detection using PPG signal and combined deep CNN-MLP network / Y. Hasanpoor, K. Motaman, B. Tarvirdzadeh, K. Alipour, M. Ghamari // 2022 29th National and 7th Intern. Iranian Conf. on Biomed. Engin. (ICBME). Tehran, Iran, Islamic Republic: IEEE, 2022. P. 223–228. doi: 10.1109/icbme57741.2022.10052957.
16. On-device transfer learning for personalising psychological stress modelling using a convolutional neural network / K. Woodward, E. Kanjo, D. J. Brown, T. M. McGinnity // Conf.: On-device Intelligence Workshop, MLSys. Austin, Texas, 2020. URL: <https://arxiv.org/ftp/arxiv/papers/2004/2004.01603.pdf> (дата обращения 21.08.2023).
17. A sensitivity analysis of biophysiological responses of stress for wearable sensors in connected health / T. Iqbal, P. Redon-Lurbe, A. J. Simpkin, A. Elahi, S. Ganly, W. Wijns, A. Shahzad // IEEE Access. 2021. Vol. 9. P. 93567–93579. doi: 10.1109/access.2021.3082423.

18. Siirtola P. Continuous stress detection using the sensors of commercial smartwatch // *Adjunct Proc. of the 2019 ACM Intern. Joint Conf. on Pervasive and Ubiquitous Comp. and Proc. of the 2019 ACM Intern. Symp. on Wearable Comp.* 2019. P. 1198–1201. doi: 10.1145/3341162.3344831. URL: <https://arxiv.org/ftp/arxiv/papers/2004/2004.01603.pdf> (дата обращения 21.08.2023).
19. Lai K., Yanushkevich S. N., Shmerko V. P. Intelligent stress monitoring assistant for first responders // *IEEE Access*. 2021. Т. 9. P. 25314–25329. doi: 10.1109/access.2021.3057578.
20. DeStress: deep learning for unsupervised identification of mental stress in firefighters from heart-rate variability (HRV) data / A. Oskooei, S. M. Chau, J. Weiss, A. Sridhar, M. R. Martínez, B. Michel // *Explainable AI in Healthcare and Medicine: Building a Culture of Transparency and Accountability*. 2021. P. 93–105. doi: 10.1007/978-3-030-53352-6_9.
21. Deep learning with wearable based heart rate variability for prediction of mental and general health / L. V. Coutts, D. Plans, A. W. Brown, J. Collomosse // *J. of Biomed. Informatics*. 2020. Т. 112. P. 103610. doi: 10.1016/j.jbi.2020.103610. URL: <https://www.sciencedirect.com/science/article/pii/S1532046420302380?via%3Dihub> (дата обращения 21.08.2023).
22. Lima R., de Noronha Osório D. F., Gamboa H. Heart rate variability and electrodermal activity in mental stress aloud: Predicting the outcome // *Biosignals*. 2019. P. 42–51. doi: 10.5220/0007355200420051. URL: https://pdfs.semanticscholar.org/b5f7/095bae46986a142c93f2890e6ce33624522c.pdf?_gl=1*1uur6g4*_ga*ODY3NjczNzkwLjE2Njg5ODYwMzY.*_ga_H7P4ZT52H5*MTcwMDA4NTg4Mi45LjAuMTcwMDA4NTg4NC41OC4wLjA (дата обращения 21.08.2023).
23. Posada-Quintero H. F., Bolkhovskiy J. B. Machine learning models for the identification of cognitive tasks using autonomic reactions from heart rate variability and electrodermal activity // *Behavioral Sci.* 2019. Т. 9, № 4. P. 45. doi: 10.3390/bs9040045.
24. Detection of subtle stress episodes during UX evaluation: Assessing the performance of the WESAD bio-signals dataset / A. Liapis, E. Faliagka, C. Katsanos, C. Antonopoulos, N. Voros // *Human-Computer Interaction – INTERACT 2021: 18th IFIP TC 13 Intern. Conf., Proc., Part III* 18. Bari, Italy: Springer Intern. Publishing, 2021. P. 238–247. doi: 10.1007/978-3-030-85613-7_17.
25. Towards an anxiety and stress recognition system for academic environments based on physiological features / J. Rodríguez-Arce, L. Lara-Flores, O. Portillo-Rodríguez, R. Martínez-Méndez // *Comp. Methods and Programs in Biomed.* 2020. Т. 190. P. 105408. doi: 10.1016/j.cmpb.2020.105408.
26. IoT based psychological and physical stress evaluation in sportsmen using heart rate variability / N. Jin, X. Zhang, Z. Hou, I. Sanz-Prieto, B. S. Mohammed // *Aggression and Violent Behavior*. 2021. P. 101587. doi: 10.1016/j.avb.2021.101587. URL: https://www.researchgate.net/publication/349876374_IoT_based_psychological_and_physical_stress_evaluation_in_sportsmen_using_heart_rate_variability (дата обращения 21.08.2023).
27. Modeling perceived stress via HRV and accelerometer sensor streams / M. Wu, H. Cao, H. L. Nguyen, K. Surmacz, C. Hargrove // 2015 37th Ann. Intern. Conf. of the IEEE Engin. in Med. and Biol. Society (EMBC). Milan, Italy: IEEE, 2015. P. 1625–1628. doi: 10.1109/embc.2015.7318686.
28. Quinlan J. R. C4.5: programs for machine learning. Elsevier, 2014.
29. Indikawati F. I., Winiarti S. Stress detection from multimodal wearable sensor data // *IOP Conf. Series: Materials Sci. and Engin.* IOP Publishing, 2020. Т. 771, № 1. P. 012028. doi: 10.1088/1757-899x/771/1/012028.
30. Evaluating visual photoplethysmography method / D. Talukdar, L. F. de Deus, N. Sehgal, L. F. De Deus // *Cureus*. 2022. Т. 14, № 7. doi: 10.7759/cureus.26871. URL: https://www.researchgate.net/publication/355655656_Evaluating_Visual_Photoplethysmography_Method (дата обращения 21.08.2023).
31. Hantono B. S., Nugroho L. E., Santosa P. I. Mental stress detection via heart rate variability using machine learning // *Intern. J. on Electrical Engin. and Informatics*. 2020. Т. 12, № 3. P. 431–444.
32. Siirtola P., Rönning J. Comparison of regression and classification models for user-independent and personal stress detection // *Sensors*. 2020. Т. 20, № 16. P. 4402. doi: 10.3390/s20164402.
33. Albaladejo-González M., Ruipérez-Valiente J. A., Gómez Mármol F. Evaluating different configurations of machine learning models and their transfer learning capabilities for stress detection using heart rate // *J. of Ambient Intelligence and Humanized Comp.* 2022. Vol. 14 (100) P. 1–11. doi: 10.1007/s12652-022-04365-z. URL: https://www.researchgate.net/publication/363034928_Evaluating_different_configurations_of_machine_learning_models_and_their_transfer_learning_capabilities_for_stress_detection_using_heart_rate (дата обращения 21.08.2023).
34. Dalmeida K. M., Masala G. L. HRV features as viable physiological markers for stress detection using wearable devices // *Sensors*. 2021. Т. 21, № 8. P. 2873. doi: 10.3390/s21082873.
35. Real-time detection of acute cognitive stress using a convolutional neural network from electrocardiographic signal / J. He, K. Li, X. Liao, P. Zhang, N. Jiang // *IEEE Access*. 2019. Vol. 7. P. 42710–42717. doi: 10.1109/access.2019.2907076.
36. Classification of mental stress from wearable physiological sensors using image-encoding-based deep neural network / S. Ghosh, S. Kim, M. F. Ijaz, P. K. Singh, M. Mahmud // *Biosensors*. 2022. Т. 12, № 12. P. 1153. doi: 10.3390/bios12121153.
37. Dynamic Alignment and Fusion of Multimodal Physiological Patterns for Stress Recognition / X. Zhang, X. Wei, Z. Zhou, Q. Zhao, S. Zhang, Y. Yang, R. Li, B. Hu // *IEEE Transactions on Affective Comp.* 2023. P. 1–12. doi: 10.1109/taffc.2023.3290177.
38. Xu Q., Nwe T. L., Guan C. Cluster-based analysis for personalized stress evaluation using physiological signals // *IEEE J. of Biomed. and Health Informatics*.

2014. Т. 19. № 1. P. 275–281. doi: 10.1109/jbhi.2014.2311044.

39. Analysing the performance of stress detection models on consumer-grade wearable devices / V. T. Ninh, S. Smyth, M. T. Tran, C. Gurrin. 2022. doi: 10.3233/faia210050. URL: https://www.researchgate.net/publication/354635121_Analysing_the_Performance_of_Stress_Detection_Models_on_Consumer-Grade_Wearable_Devices (дата обращения 21.08.2023).

40. Garcia-Ceja E., Brena R. Building personalized activity recognition models with scarce labeled data based on class similarities // Ubiquitous Comp. and Ambient Intelligence. Sensing, Processing, and Using Environmental Information: 9th Intern. Conf., UCAMI 2015. Puerto Varas, Chile: Springer International Publishing, 2015. P. 265–276. doi: 10.1007/978-3-319-26401-1_25.

41. Stress sense: Detecting stress in unconstrained acoustic environments using smartphones / H. Lu,

D. Frauendorfer, M. Rabbi, M. S. Mast, G. T. Chittaranjan, A. T. Campbell, D. Gatica-Perez, T. Choudhury // Proc. of the 2012 ACM Conf. on Ubiquitous Comp. 2012. P. 351–360. doi: 10.1145/2370216.2370270. URL: https://www.researchgate.net/publication/262208784_StressSense_Detecting_stress_in_unconstrained_acoustic_environments_using_smartphones (дата обращения 21.08.2023).

42. Relation of resting heart rate to risk for all-cause mortality by gender after considering exercise capacity (the Henry Ford exercise testing project) / A. I. Aladin, S. P. Whelton, M. H. Al-Mallah, M. J. Blaha, S. J. Keteyian, S. P. Juraschek, J. Rubin, C. A. Brawner, E. D. Michos // The Am. J. of Cardiol. 2014. Т. 114, № 11. P. 1701–1706. doi: 10.1016/j.amjcard.2014.08.042.

43. Cawley G. C., Talbot N. L. C. Efficient leave-one-out cross-validation of kernel fisher discriminant classifiers // Pattern Recognition. 2003. Т. 36, № 11. P. 2585–2592. doi: 10.1016/s0031-3203(03)00136-5.

Информация об авторах

Доброхвалов Максим Олегович – аспирант кафедры математического обеспечения и применения ЭВМ СПбГЭТУ «ЛЭТИ».

E-mail: night1337bot@gmail.com

<https://orcid.org/0000-0002-0571-5836>

Филатов Антон Юрьевич – канд. техн. наук, доцент кафедры математического обеспечения и применения ЭВМ СПбГЭТУ «ЛЭТИ».

E-mail: aifilatov@etu.ru

<https://orcid.org/0000-0003-4298-8523>

References

1. Selye H. The stress of life. New York: McGraw-Hill, 1976. 516 с.

2. Kasl S. V. Stress and health // Ann. Rev. of Public Health. 1984. Т. 5, № 1. P. 319–341.

3. Bobade P., Vani M. Stress detection with machine learning and deep learning using multimodal physiological data // 2020 Second Intern. Conf. on Inventive Research in Comp. Appl. (ICIRCA). Coimbatore, India: IEEE, 2020. P. 51–57. doi: 10.1109/icirca48905.2020.9183244.

4. GSR analysis for stress: Development and validation of an open source tool for noisy naturalistic GSR data / S. A. Aqajari, E. K. Naeni, M. A. Mehrabadi, S. Labbaf, A. M. Rahmani, N. Dutt. 2020. URL: <https://arxiv.org/ftp/arxiv/papers/2005/2005.01834.pdf> (data obraschenija 21.08.2023).

5. Sah R. K., Ghasemzadeh H. Stress classification and personalization: Getting the most out of the least. 2021. URL: <https://arxiv.org/pdf/2107.05666.pdf> (data obraschenija 21.08.2023).

6. Detection of mental stress due to oral academic examination via ultra-short-term HRV analysis / R. Castaldo, W. Xu, P. Melillo, L. Pecchia, L. Santamaria, C. James // 2016 38th Ann. Intern. Conf. of the IEEE Engin. in Med. and Biol. society (EMBC). IEEE, 2016. P. 3805–3808. doi: 10.1109/embc.2016.7591557.

7. Objective detection of chronic stress using physiological parameters / R. M. Al Abdi, A. E. Alhithary, E. W. Abdul Hay, A. K. Al-Bashir // Med. & Boil. Engin. & Comp. 2018. Т. 56. P. 2273–2286. doi: 10.1007/s11517-018-1854-8.

8. Ambulatory and laboratory stress detection based on raw electrocardiogram signals using a convolutional neural network / H. M. Cho, H. Park, S. Y. Dong, I. Youn // Sensors. 2019. Т. 19. № 20. P. 4408. doi: 10.3390/s19204408.

9. He J., Jiang N. Optimizing probability threshold of convolution neural network to improve HRV-based acute stress detection performance // 2019 41st Ann. Intern. Conf. of the IEEE Engin. in Med. and Biol. Society (EMBC). Berlin, Germany: IEEE, 2019. P. 5318–5321. doi: 10.1109/embc.2019.8856853.

10. Introducing WESAD, a multimodal dataset for wearable stress and affect detection / P. Schmidt, A. Reiss, R. Duerichen, C. Marberger, K. Van Laerhoven // Proc. of the 20th ACM Intern. Conf. on Multimodal Interaction. 2018. P. 400–408. doi: 10.1145/3242969.3242985.

11. Giannakakis G., Marias K., Tsiknakis M. A stress recognition system using HRV parameters and machine learning techniques // 2019 8th Intern. Conf. on Affective Comp. and Intelligent Interaction Workshops and Demos

(ACI IW). Cambridge, UK: IEEE, 2019. P. 269–272. doi: 10.1109/aciw.2019.8925142.

12. Dalal S., Khalaf O. I. Prediction of occupation stress by implementing convolutional neural network techniques // *J. of Cases on Information Technol. (JCIT)*. 2021. T. 23, № 3. P. 27–42. doi: 10.4018/jcit.20210701.0a3.

13. ECG-based biometric under different psychological stress states / R. Zhou, C. Wang, P. Zhang, X. Chen, L. Du, P. Wang, Z. Zhao, M. Du, Z. Fang // *Comp. Methods and Programs in Biomed.* 2021. T. 202. P. 106005. doi: 10.1016/j.cmpb.2021.106005.

14. UBFC-phys: A multimodal database for psychophysiological studies of social stress / R. M. Sabour, Y. Benezeth, P. De Oliveira, J. Chappe, F. Yang // *IEEE Transactions on Affective Comp.* 2021. Vol. 14, № 1. P. 622–636. doi: 10.1109/taffc.2021.3056960. URL: <https://ieeexplore.ieee.org/document/9346017> (data obraschenija 21.08.2023).

15. Stress Detection Using PPG Signal and Combined Deep CNN-MLP Network / Y. Hasanpoor, K. Motaman, B. Tarvirdizadeh, K. Alipour, M. Ghamari // 2022 29th National and 7th Intern. Iranian Conf. on Biomed. Engin. (ICBME). Tehran, Iran, Islamic Republic: IEEE, 2022. P. 223–228. doi: 10.1109/icbme57741.2022.10052957.

16. On-device transfer learning for personalising psychological stress modelling using a convolutional neural network / K. Woodward, E. Kanjo, D. J. Brown, T. M. McGinness // *Conf.: On-device Intelligence Workshop, MLSys*. Austin, Texas, 2020. URL: <https://arxiv.org/ftp/arxiv/papers/2004/2004.01603.pdf> (data obraschenija 21.08.2023).

17. A sensitivity analysis of biophysiological responses of stress for wearable sensors in connected health / T. Iqbal, P. Redon-Lurbe, A. J. Simpkin, A. Elahi, S. Ganly, W. Wijns, A. Shahzad // *IEEE Access*. 2021. Vol. 9. P. 93567–93579. doi: 10.1109/access.2021.3082423.

18. Siirtola P. Continuous stress detection using the sensors of commercial smartwatch // *Adjunct Proc. of the 2019 ACM Intern. Joint Conf. on Pervasive and Ubiquitous Comp. and Proc. of the 2019 ACM Intern. Symp. on Wearable Comp.* 2019. P. 1198–1201. doi: 10.1145/3341162.3344831. URL: <https://arxiv.org/ftp/arxiv/papers/2004/2004.01603.pdf> (data obraschenija 21.08.2023).

19. Lai K., Yanushkevich S. N., Shmerko V. P. Intelligent stress monitoring assistant for first responders // *IEEE Access*. 2021. T. 9. P. 25314–25329. doi: 10.1109/access.2021.3057578.

20. DeStress: deep learning for unsupervised identification of mental stress in firefighters from heart-rate variability (HRV) data / A. Oskooei, S. M. Chau, J. Weiss, A. Sridhar, M. R. Martínez, B. Michel // *Explainable AI in Healthcare and Medicine: Building a Culture of Transparency and Accountability*. 2021. P. 93–105. doi: 10.1007/978-3-030-53352-6_9.

21. Deep learning with wearable based heart rate variability for prediction of mental and general health / L. V. Coutts, D. Plans, A. W. Brown, J. Collomosse // *J. of Biomed. Informatics*. 2020. T. 112. P. 103610. doi: 10.1016/j.jbi.2020.103610. URL: <https://www.sciencedi>

<rect.com/science/article/pii/S1532046420302380?via%3Dihub> (data obraschenija 21.08.2023).

22. Lima R., de Noronha Osório D. F., Gamboa H. Heart rate variability and electrodermal activity in mental stress aloud: Predicting the outcome // *Biosignals*. 2019. P. 42–51. doi: 10.5220/0007355200420051. URL: https://pdfs.semanticscholar.org/b5f7/095bae46986a142c93f2890e6ce33624522c.pdf?_gl=1*1uur6g4*_ga*ODY3NjczNzkwljE2Njg5ODYwMzY.*_ga_H7P4ZT52H5*MTcwMDA4NTg4Mi45LjAuMTcwMDA4NTg4NC41OC4wLjA (data obraschenija 21.08.2023).

23. Posada-Quintero H. F., Bolkhovskiy J. B. Machine learning models for the identification of cognitive tasks using autonomic reactions from heart rate variability and electrodermal activity // *Behavioral Sci.* 2019. T. 9, № 4. P. 45. doi: 10.3390/bs9040045.

24. Detection of subtle stress episodes during UX evaluation: Assessing the performance of the WESAD bio-signals dataset / A. Liapis, E. Faliagka, C. Katsanos, C. Antonopoulos, N. Voros // *Human-Computer Interaction – INTERACT 2021: 18th IFIP TC 13 Intern. Conf., Proc., Part III 18*. Bari, Italy: Springer Intern. Publishing, 2021. P. 238–247. doi: 10.1007/978-3-030-85613-7_17.

25. Towards an anxiety and stress recognition system for academic environments based on physiological features / J. Rodríguez-Arce, L. Lara-Flores, O. Portillo-Rodríguez, R. Martínez-Méndez // *Comp. Methods and Programs in Biomed.* 2020. T. 190. P. 105408. doi: 10.1016/j.cmpb.2020.105408.

26. IOT based psychological and physical stress evaluation in sportsmen using heart rate variability / N. Jin, X. Zhang, Z. Hou, I. Sanz-Prieto, B. S. Mohammed // *Aggression and Violent Behavior*. 2021. P. 101587. doi: 10.1016/j.avb.2021.101587. URL: https://www.researchgate.net/publication/349876374_IoT_based_psychological_and_physical_stress_evaluation_in_sportsmen_using_heart_rate_variability (data obraschenija 21.08.2023).

27. Modeling perceived stress via HRV and accelerometer sensor streams / M. Wu, H. Cao, H. L. Nguyen, K. Surmacz, C. Hargrove // 2015 37th Ann. Intern. Conf. of the IEEE Engin. in Med. and Biol. Society (EMBC). Milan, Italy: IEEE, 2015. P. 1625–1628. doi: 10.1109/embc.2015.7318686.

28. Quinlan J. R. C4.5: programs for machine learning. Elsevier, 2014.

29. Indikawati F. I., Winiarti S. Stress detection from multimodal wearable sensor data // *IOP Conf. Series: Materials Sci. and Engin.* IOP Publishing, 2020. T. 771, № 1. P. 012028. doi: 10.1088/1757-899x/771/1/012028.

30. Evaluating visual photoplethysmography method / D. Talukdar, L. F. de Deus, N. Sehgal, L. F. De Deus // *Cureus*. 2022. T. 14, № 7. doi: 10.7759/cureus.26871. URL: https://www.researchgate.net/publication/355655656_Evaluating_Visual_Photoplethysmography_Method (data obraschenija 21.08.2023).

31. Hantono B. S., Nugroho L. E., Santosa P. I. Mental stress detection via heart rate variability using machine learning // *Intern. J. on Electrical Engin. and Informatics*. 2020. T. 12, № 3. P. 431–444.

32. Siirtola P., Rönning J. Comparison of regression and classification models for user-independent and personal stress detection // *Sensors*. 2020. T. 20, № 16. P. 4402. doi: 10.3390/s20164402.
33. Albaladejo-González M., Ruipérez-Valiente J. A., Gómez Mármol F. Evaluating different configurations of machine learning models and their transfer learning capabilities for stress detection using heart rate // *J. of Ambient Intelligence and Humanized Comp.* 2022. Vol. 14 (100) P. 1–11. doi: 10.1007/s12652-022-04365-z. URL: https://www.researchgate.net/publication/363034928_Evaluating_different_configurations_of_machine_learning_models_and_their_transfer_learning_capabilities_for_stress_detection_using_heart_rate (data obraschenija 21.08.2023).
34. Dalmeida K. M., Masala G. L. HRV features as viable physiological markers for stress detection using wearable devices // *Sensors*. 2021. T. 21, № 8. P. 2873. doi: 10.3390/s21082873.
35. Real-time detection of acute cognitive stress using a convolutional neural network from electrocardiographic signal / J. He, K. Li, X. Liao, P. Zhang, N. Jiang // *IEEE Access*. 2019. Vol. 7. P. 42710–42717. doi: 10.1109/access.2019.2907076.
36. Classification of mental stress from wearable physiological sensors using image-encoding-based deep neural network / S. Ghosh, S. Kim, M. F. Ijaz, P. K. Singh, M. Mahmud // *Biosensors*. 2022. T. 12, № 12. P. 1153. doi: 10.3390/bios12121153.
37. Dynamic Alignment and Fusion of Multimodal Physiological Patterns for Stress Recognition / X. Zhang, X. Wei, Z. Zhou, Q. Zhao, S. Zhang, Y. Yang, R. Li, B. Hu // *IEEE Transactions on Affective Comp.* 2023. P. 1–12. doi: 10.1109/taffc.2023.3290177.
38. Xu Q., Nwe T. L., Guan C. Cluster-based analysis for personalized stress evaluation using physiological signals // *IEEE J. of Biomed. and Health Informatics*. 2014. T. 19. № 1. P. 275–281. doi: 10.1109/jbhi.2014.2311044.
39. Analysing the performance of stress detection models on consumer-grade wearable devices / V. T. Ninh, S. Smyth, M. T. Tran, C. Gurrin. 2022. doi: 10.3233/faia210050. URL: https://www.researchgate.net/publication/354635121_Analysing_the_Performance_of_Stress_Detection_Models_on_Consumer-Grade_Wearable_Devices (data obraschenija 21.08.2023).
40. Garcia-Ceja E., Brena R. Building personalized activity recognition models with scarce labeled data based on class similarities // *Ubiquitous Comp. and Ambient Intelligence. Sensing, Processing, and Using Environmental Information: 9th Intern. Conf., UCAmI 2015. Puerto Varas, Chile: Springer International Publishing, 2015. P. 265–276. doi: 10.1007/978-3-319-26401-1_25.*
41. Stress sense: Detecting stress in unconstrained acoustic environments using smartphones / H. Lu, D. Frauendorfer, M. Rabbi, M. S. Mast, G. T. Chittaranjan, A. T. Campbell, D. Gatica-Perez, T. Choudhury // *Proc. of the 2012 ACM Conf. on Ubiquitous Comp.* 2012. P. 351–360. doi: 10.1145/2370216.2370270. URL: https://www.researchgate.net/publication/262208784_StressSense_Detecting_stress_in_unconstrained_acoustic_environments_using_smartphones (data obraschenija 21.08.2023).
42. Relation of resting heart rate to risk for all-cause mortality by gender after considering exercise capacity (the Henry Ford exercise testing project) / A. I. Aladin, S. P. Whelton, M. H. Al-Mallah, M. J. Blaha, S. J. Keteyian, S. P. Juraschek, J. Rubin, C. A. Brawner, E. D. Michos // *The Am. J. of Cardiol.* 2014. T. 114, № 11. P. 1701–1706. doi: 10.1016/j.amjcard.2014.08.042.
43. Cawley G. C., Talbot N. L. C. Efficient leave-one-out cross-validation of kernel fisher discriminant classifiers // *Pattern Recognition*. 2003. T. 36, № 11. P. 2585–2592. doi: 10.1016/s0031-3203(03)00136-5.

Information about the authors

Maksim O. Dobrokhvalov – postgraduate student of the Department of Mathematical Support and Computer Applications of Saint Petersburg Electrotechnical University.

E-mail: night1337bot@gmail.com

<https://orcid.org/0000-0002-0571-5836>

Anton Yu. Filatov – Cand. Sci. (Eng.), Associate Professor of the Department of Mathematical Support and Computer Applications of Saint Petersburg Electrotechnical University.

E-mail: aifilatov@etu.ru

<https://orcid.org/0000-0003-4298-8523>

Статья поступила в редакцию 18.09.2023; принята к публикации после рецензирования 30.11.2023; опубликована онлайн 30.01.2024.

Submitted 18.09.2023; accepted 30.11.2023; published online 30.01.2024.